

## **NOTA TÉCNICA**

# **IMPLEMENTAÇÃO DA METODOLOGIA SWIFT PARA ESTIMAR A POBREZA GLOBAL ABSOLUTA EM Cabo Verde - 2016 a 2022**



PARCEIROS



THE WORLD BANK

## **INSTITUTO NACIONAL DE ESTATÍSTICA**

### **Implementação da Metodologia SWIFT para Estimar a Pobreza Global Absoluta em Cabo Verde de 2016 a 2022**

#### **CONSELHO DIRETIVO**

##### **PRESIDENTE**

João de Pina Mendes Cardoso

##### **VICE-PRESIDENTE**

Fernando Lopes Rocha

##### **VOGAL**

Annie Pereira Tavares Sanches

#### **EQUIPA TÉCNICA INE**

Bruno Barros            Estatístico

Danilton Tavares      Estatístico

Teresa Moniz            Estaticista

#### **EQUIPA TÉCNICA BANCO MUNDIAL**

Eduardo A. Malásquez            Economista Sénior, ESAPV

Oscar Barriga Cabanillas        Economista, EAWPV

Rogelio Granguillhome Ochoa    Consultor, EAWPV

#### **EDITOR:**

Instituto Nacional de Estatística

Rua da Caixa Económica, N° 18,

C.P. n° 116, Fazenda – Praia

Tel: (238) 261 38 27 / Fax: +238 261 16 56

Email: [inecv@ine.gov.cv](mailto:inecv@ine.gov.cv)

#### **DESIGN E COMPOSIÇÃO**

Gabinete de Comunicação, Difusão e Cooperação,

© Copyright 2023

Instituto Nacional de Estatística

#### **DATA PUBLICAÇÃO**

Abril 2023

## **DESCRIÇÃO**

Esta Nota Técnica é o resultado de uma colaboração entre uma equipa técnica do Instituto Nacional de Estatística de Cabo Verde (INE-CV), composto por Bruno Barros (Estatístico), Danilton Tavares (Estatístico) e Teresa Moniz (Estatística); e uma equipa da Prática Global de Pobreza e Equidade do Banco Mundial, incluindo Oscar Barriga Cabanillas (Economista, ESAPV) e Rogelio Granguillhome Ochoa (Consultor, EAWPV), sob a supervisão de Eduardo A. Malásquez (Economista Sénior, EAWPV). Os autores agradecem Nobuo Yoshida (economista-chefe, EAEPV) e Danielle Vitória Aron (Consultor de Curto Prazo, CDIMA) pelo seu aconselhamento técnico, o apoio de Gabriela P. B. Cecchini (Consultora, EAWPV), e as orientações recebidas de João de Pina Mendes Cardoso (Presidente do Conselho Diretivo, INE), Fernando Rocha (Vice-presidente do Conselho Diretivo, INE) e Eneida Fernandez (Representante Residente do Banco Mundial em Cabo Verde) e o pessoal do INE.

## ÍNDICE

<b>DESCRIÇÃO</b> .....	3
<b>INTRODUÇÃO E CONTEXTO</b> .....	5
<b>METODOLOGIA</b> .....	6
<b>ESTIMATIVAS DE POBREZA</b> .....	14
<b>CONCLUSÃO</b> .....	21
<b>APÊNDICE</b> .....	22

## INTRODUÇÃO E CONTEXTO

**O acompanhamento da evolução da pobreza e da desigualdade é essencial para fundamentar a conceção e a avaliação das políticas públicas.** Na ausência de dados atualizados sobre a pobreza, torna-se difícil monitorizar as condições de vida dos pobres e desenvolver uma agenda para melhorar as suas condições de vida. No entanto, a produção de estatísticas sobre a pobreza tipicamente exige inquéritos fiáveis às despesas ou aos rendimentos dos agregados familiares, que são complexos e demandam bastante tempo, tanto do ponto de vista das agências estatísticas quanto dos agregados familiares que fornecem as informações (por exemplo, ao responder de forma pormenorizada a questionários de consumo) e recursos, particularmente no contexto do inquérito realizado em Cabo Verde. Compreender o perfil dos pobres e como ele varia segundo as características dos agregados familiares, da geografia e das comunidades, é valioso para melhor direcionar os recursos para os bens e serviços que podem proporcionar maior impacto no bem-estar dos agregados familiares.

**O mais recente Inquérito às Despesas e Receitas Familiares (IDRF) em Cabo Verde foi realizado em 2015, de maneira que os últimos números oficiais sobre pobreza e desigualdade remontam a este ano.** Embora um novo inquérito IDRF 2022/23 esteja atualmente a ser implementado, que fornecerá um retrato atualizado sobre os níveis da pobreza e desigualdade no país, espera-se que os resultados deste inquérito sejam divulgados apenas em 2024, quando haverá um hiato de quase dez anos na evolução dos indicadores de bem-estar ao nível dos agregados familiares.

**Para preencher esta falta de dados para a tomada de decisões, propõe-se uma metodologia para estimar os indicadores anuais da pobreza<sup>1</sup> entre 2016 e 2022.** Considerando a importância da medição da pobreza monetária para avaliar o desempenho socioeconómico, utiliza a metodologia SWIFT-plus, um desenvolvimento metodológico recente para transpor a falta de dados e avaliar a evolução da pobreza monetária ao longo do tempo. A imputação da pobreza utiliza como base a informação do IDRF de 2015 para estimar um modelo de predição do estado

---

<sup>1</sup> Este documento visa estimar a evolução da Pobreza Monetária Absoluta Global, tal como definida em INE, 2018: Documento Metodológico IDRF 2015: Metodologia da Medição da Pobreza Monetária em Cabo Verde. Conforme descrito no documento, o limiar da pobreza global em 2015 no país era de 95 461 ECV (zonas urbanas) e 81 710 ECV (zonas rurais) por pessoa e por ano. Deve-se notar, portanto, que as estimativas se referem à Pobreza Absoluta Global e não à Pobreza Absoluta Extrema.

da pobreza, que é posteriormente imputado no Inquérito Multi-Objetivo Contínuo (IMC), realizado anualmente pelo INE-CV, para o período 2016-2022 (exceto para 2021, quando o IMC não foi implementado). Este inquérito secundário não contém informações que permitam estimar diretamente as taxas da pobreza, tais como um vetor das despesas das famílias. Os resultados aqui discutidos baseiam-se na implementação da metodologia, utilizando a informação prontamente disponível. Estas estimativas poderão ser melhoradas quando estiverem disponíveis informações adicionais relevantes, como o PIB per capita a nível das ilhas até 2022 ou informações atualizadas sobre as condições climáticas.

**Antes da pandemia de COVID-19 em 2020, a redução da pobreza em Cabo Verde estava entre as mais bem-sucedidas da África Subsariana.** As projeções de pobreza do modelo SWIFT-plus mostram uma tendência decrescente de 2015 a 2019, caindo de 35,2% para 27,7%. A COVID-19 produziu a maior contração económica de que há registo (19,3%) em 2020 e expôs as vulnerabilidades económicas do país, perturbando os setores de serviços e de hotelaria e provocando um aumento da pobreza em quase 4,0 pontos percentuais (atingindo 31,3% em 2020), regressando a um nível comparável ao de 2016 (31,8%). Após o declínio induzido pela COVID-19, a economia voltou a crescer em 2021, e, mais ainda, em 2022. As projeções mostram uma queda na taxa de pobreza para 28,1% em 2022, mas esta permanece acima dos níveis pré-pandemia de 2019.

## **METODOLOGIA**

**Em situações em que estão disponíveis inquéritos intermédios, as abordagens de imputação inquérito a inquérito (*survey-to-survey*, S2S) fornecem uma ferramenta para imputar as despesas ou rendimentos dos agregados familiares noutra conjunto de dados de inquérito existente.** Estas imputações permitem medir a incidência da pobreza e a prosperidade partilhada de uma forma mais frequente e eficaz em termos de custos e em contextos em que os inquéritos às despesas e/ou rendimentos não estejam disponíveis. Nós utilizamos as etapas de imputações S2S desenvolvidas sob a metodologia SWIFT (Yoshida et al. 2015). As aplicações originais do modelo SWIFT destinavam-se a desenvolver módulos de inquéritos curtos aos quais a pobreza poderia ser imputada para fornecer estimativas atualizadas.

**O modelo SWIFT introduz alguns ajustes e modificações à metodologia de imputação inquérito a inquérito existente para melhorar o desempenho do modelo.** Estes incluem testes adicionais para evitar a inconsistência do modelo, bem como a integração de princípios de Aprendizado de Máquina (*Machine Learning*, ML), Validação Cruzada (*Cross-Validation*, CV) e Imputação Múltipla (*Multiple Imputation*, MI) no processo de estimação da pobreza. O resto deste documento discute a abordagem das imputações inquérito a inquérito (S2S) e apresenta os dados e resultados de modelação utilizados no caso de Cabo Verde.

### **Dados e pressupostos do modelo**

**O modelo SWIFT identifica perguntas sobre variáveis correlacionadas à pobreza e, baseado nestas variáveis, imputa as despesas (ou os rendimentos) dos agregados familiares num inquérito em que não foram recolhidos dados sobre despesas (ou rendimentos).** Os correlatos da pobreza geralmente incluem variáveis como tamanho do agregado familiar, proporção de mulheres entre os membros do agregado, escolaridade, condição de emprego, propriedade de bens de consumo duráveis, condições da habitação, localização, etc.

$$(1) \quad y_h = x_h \beta_s + u_h$$
$$u_h \sim N(0, \sigma_t)$$
$$\hat{\beta}_s \sim N(\hat{\beta}_t, \hat{\sigma}_{\beta t})$$

**As informações sobre o IDRF de 2015 constituem a base para “ensaiar” o modelo SWIFT.** O ensaio do modelo é fundamental para o bom desempenho dos indicadores da pobreza e desigualdade. Em Cabo Verde, o mais recente Inquérito às Despesas e Receitas Familiares (IDRF) ocorreu em 2015. A partir dos dados do IDRF 2015, estimamos o modelo a partir da equação (1), em que  $y_h$  corresponde ao logaritmo natural das despesas do agregado familiar  $h$ ,  $x_h$  corresponde a um vetor ( $k \times 1$ ) dos correlatos da pobreza do agregado familiar  $h$ , e  $\beta_s$  é um vetor de coeficientes dos correlatos da pobreza escolhidos aleatoriamente a partir de uma distribuição normal multivariada de  $N(\hat{\beta}_t, \hat{\sigma}_{\beta t})$ , onde  $k$  é o número de variáveis. Tanto as médias ( $\hat{\beta}_t$ ) como a matriz de variância-covariância ( $\hat{\sigma}_{\beta t}$ ) e o resíduo  $u_h$  são extraídos de uma distribuição normal e estimados a partir do conjunto de dados IDRF de 2015.

**O modelo para prever a pobreza é imputado em múltiplas rondas do Inquérito Multi-Objetivo Contínuo (IMC) anual que foram recolhidas entre 2016 e 2022 (excluindo 2021).** Antes de estimar a equação (1), é fundamental identificar as variáveis comuns aos inquéritos IDRF e IMC,

uma vez que são a base para as imputações da pobreza. No caso do IMC, os questionários dos anos até 2019 e de 2022 incluíram módulos sobre características do agregado familiar e da habitação, sobre acesso aos serviços e sobre mercados de trabalho. No entanto, na vaga de 2020 do IMC, os módulos sobre características da habitação e sobre acesso aos serviços não foram incluídos como parte do IMC<sup>2</sup>. Estimamos um modelo que utiliza as informações disponíveis no IMC 2016 a 2022, mas, como verificação de robustez, também estimamos um modelo que se baseia no conjunto mais rico de indicadores disponíveis no IMC durante o período de 2016 a 2019. Esta situação não é incomum, uma vez que o desenho dos inquéritos por vezes muda ao longo do tempo. Para garantir a consistência das estimativas da pobreza, também calibramos modelos independentes para o período 2015-2019 e 2015-2020, usando as variáveis comuns entre anos para esses dois períodos.<sup>3</sup>

**Na interpretação destas estimativas, deve-se considerar dois elementos adicionais.** Em primeiro lugar, assumimos que a função geradora de renda dos agregados familiares muda, dependendo da sua localização. Portanto, estimamos modelos independentes para agregados familiares residentes em áreas urbanas e rurais. Isto permite um melhor ajuste para o modelo usado em cada área e, pode-se dizer, leva a melhores previsões. As estimativas nacionais da pobreza são produzidas pela reponderação da população, usando informações da World Urbanization Prospects: 2018 Revision, da Divisão de População das Nações Unidas.

Em segundo lugar, a economia de Cabo Verde é altamente dependente dos serviços, em especial do turismo, um setor que foi duramente afetado devido às perturbações associadas à pandemia de COVID-19, e que resultou na contração do PIB em 19,3%. Para captar melhor os impactos socioeconómicos da pandemia, incluímos como uma das variáveis explicativas a informação administrativa sobre as taxas de ocupação hoteleira a nível das ilhas.<sup>4</sup> **Figura 2** mostra a

---

<sup>2</sup> Devido às interrupções da COVID-19, o questionário IMC 2020 foi encurtado, enquanto a rodada de 2021 foi cancelada.

<sup>3</sup> SWIFT originalmente tinha o objetivo de desenvolver um breve inquérito que permitisse acompanhar a evolução dos indicadores da pobreza. Uma vez que os inquéritos IMC estavam disponíveis, os avanços metodológicos do SWIFT são aproveitados para produzir um estimador modificado do *proxy means test*, PMT. O PMT é um instrumento comum para produzir indicadores da pobreza na ausência desses indicadores baseados no consumo (Grosh e Baker, 1995). Conforme explicado por Gazeaud (2020), um *proxy means test* completo requer um processo em duas etapas. Em primeiro lugar, é aplicado um inquérito aprofundado a uma amostra de agregados familiares para recolher dados sobre o consumo, bem como alguns correlatos de consumo facilmente observáveis e verificáveis. Em segundo lugar, é aplicado um breve inquérito que recolhe informações sobre os mesmos correlatos de consumo e é calculado uma nova pontuação usando informações do inquérito curto.

<sup>4</sup> Banco Mundial. 2022. Cabo Verde Economic Update - Cabo Verde's Potential Digital Dividends (em Inglês). Banco Mundial, Washington, DC.

evolução das taxas de ocupação e o grande impacto que as restrições COVID tiveram na ocupação hoteleira.<sup>5</sup>

Para estimar a equação (1) seguimos quatro passos:

1. Em primeiro lugar, verificamos a evolução das variáveis ao longo do tempo para verificar se foram criadas de forma consistente e testamos para a alta multicolinearidade entre elas. A colinearidade reduz a precisão da estimação dos coeficientes de regressão, levando a maiores erros-padrão das estimativas (Corral 2020). O objetivo da remoção das variáveis altamente multicolineares é melhorar a consistência dos coeficientes entre as iterações na etapa de validação cruzada que se segue. Para isso, removemos variáveis com fator de inflação de variância (*variance inflation factor*, VIF) acima de 5.<sup>6</sup>
2. A segunda etapa concentra-se na seleção do modelo com base nos dados do IDRF 2015. Esta etapa inclui um processo de validação cruzada para identificar o modelo com melhor desempenho, mas evitando o ajuste excessivo. É importante considerar o problema do sobre ajuste, uma vez que pode levar a um modelo que tem um bom desempenho dentro da amostra IDRF 2015, mas tem um desempenho ruim fora desse conjunto de dados<sup>7</sup>. O processo de validação cruzada divide os dados do IDRF de 2015 entre uma amostra de ensaio e uma amostra de teste. Enquanto a amostra de ensaio é usada para avaliar a aptidão do modelo, a amostra de teste é usada para avaliar o desempenho do modelo e o sobre ajuste.<sup>8</sup> Muitas técnicas de aprendizado de máquina (*machine learning*) dependem da validação cruzada para determinar a complexidade de um modelo. Conforme Yoshida et al. 2015, implementamos uma validação cruzada de 5 iterações, onde um processo de seleção passo a passo (*stepwise*)

---

<sup>5</sup> As restrições da COVID-19 tiveram um grande impacto na economia de Cabo Verde, que um modelo SWIFT que usa apenas informação das características da habitação não tem variabilidade para capturar. O módulo sobre mercado de trabalho também não consegue captar toda a extensão dos choques, uma vez que, na economia altamente informal do país, as taxas de emprego reportadas caíram apenas ligeiramente, de 12,2% em 2019 para 15,3% em 2020. Por esta razão, foram exploradas informações adicionais para captar o choque económico.

<sup>6</sup> Sob a presença de multicolinearidade, o menor valor possível para um VIF é um. Existem várias regras básicas sobre o que é um VIF aceitável. Nós seguimos James et al. (2013), que recomenda a remoção de valores superiores a cinco.

<sup>7</sup> Elbers, Lanjouw, e Lanjouw A diretriz de 2002 para estimativas de pequenas áreas (*small area estimations*) recomenda que o número de variáveis em um modelo deve ser menor do que a raiz quadrada do tamanho da amostra usada para ensaiar o modelo.

<sup>8</sup> A Validação Cruzada (CV) não aborda quaisquer problemas potenciais causados por mudanças ao longo do tempo nas relações entre os correlatos da pobreza e o consumo e despesas e pela resolução do sobre ajuste. Para uma discussão completa, ver Yoshida (2019).

usa uma regressão de Mínimos Quadrados Ordinários (*Ordinary Least Squares*, OLS) para selecionar variáveis cujos coeficientes são estatisticamente significativos em um nível de significância pré-especificado. Este exercício é repetido para diferentes níveis de significância para encontrar o nível ideal, ou seja, onde o desempenho do modelo é maximizado. As variáveis disponíveis no modelo que abrange os inquéritos de 2015 a 2022, incluem o número de indivíduos do agregado familiar; o sexo, o nível de escolaridade e o setor de emprego do representante do agregado familiar; a composição etária dos membros do agregado familiar e variáveis categóricas para cada concelho. Além disso, para o modelo 2015-2019, estavam disponíveis informações sobre a propriedade de bens, como rádio, TV, carro, bem como o número de quartos, materiais do piso, acesso à eletricidade, ao esgoto e à água e descarte de lixo. Consulte a Tabela 2 no apêndice para obter os coeficientes finais para os modelos urbano e rural.

3. Usamos os Erros Quadrados Médios (*Mean Squared Errors*, MSE, em inglês) do modelo e a diferença absoluta entre as taxas da pobreza estimadas como indicadores de desempenho para determinar o limiar ideal para o nível de significância para as regressões escalonadas (entre 0,5% e 10%). O nível de significância ideal é onde a primeira estatística, o valor absoluto da diferença entre as taxas da pobreza reais e projetadas, é minimizada. Ao mesmo tempo, o MSE também fornece uma verificação adicional de sobre ajuste. Em um caso em que o MPE é minimizado em um nível de significância menor do que o nível de significância onde a diferença absoluta entre as taxas de pobreza reais e projetadas é minimizada, o nível de significância mais baixo é escolhido como o número ideal (ver Yoshida 2019).<sup>9</sup> **Figura 1** abaixo mostra o MSE para os modelos (consulte o apêndice para os erros ABS).

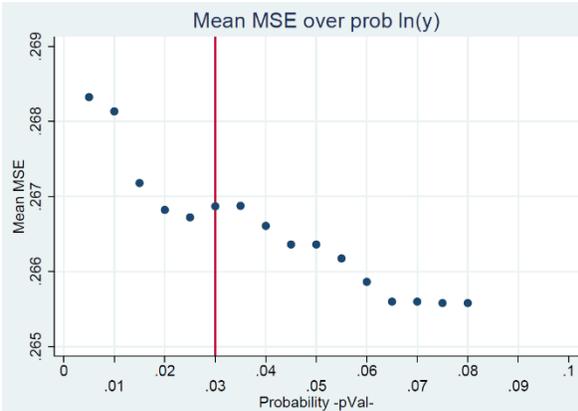
---

<sup>9</sup> Recomenda-se verificar se os sinais e valores de todos os coeficientes estimados são razoáveis. A presença de sinais não intuitivos pode indicar uma multicolinearidade que deixa o modelo instável. Nesse caso, recomenda-se a exclusão dessa variável.

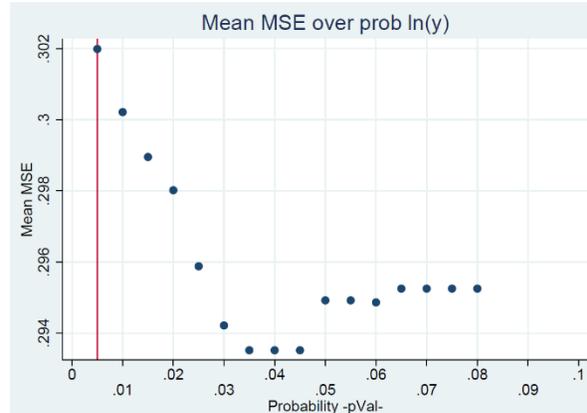
**Figura1: Resultados da seleção do modelo de validação cruzada**

**Modelo 2015-2022**

a. MPE Urbano



b. MPE Rural



**Fonte:** Cálculos do Pessoal do Banco Mundial e do INE-CV.

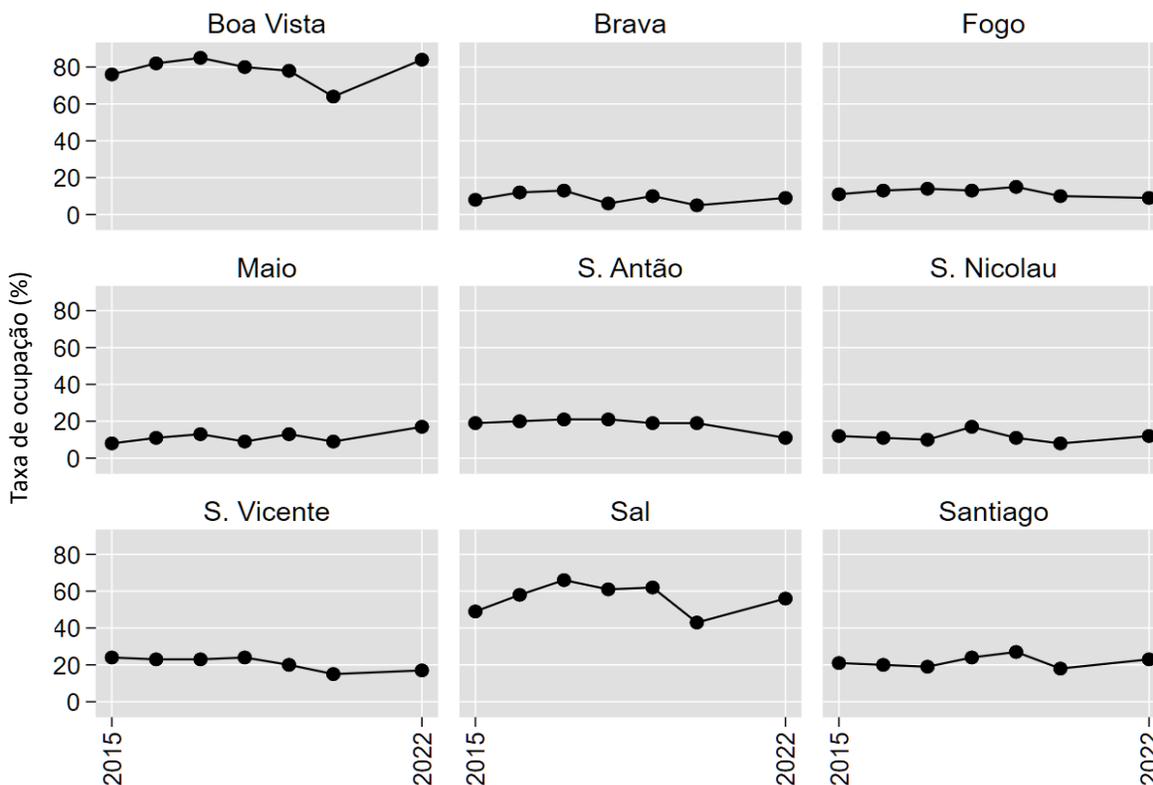
**Nota:** Resultados da validação cruzada da análise de 5 iterações utilizando dados IDRF 2015. A linha vermelha vertical identifica o valor p ideal identificado

- Uma etapa final ocorre após a seleção do modelo e consiste em imputar a pobreza tanto no IDRF 2015 quanto nos inquéritos IMC. A imputação nos dados de 2015 serve para testar ainda mais o desempenho do modelo, enquanto as imputações subsequentes nos inquéritos IMC fornecem projeções atualizadas sobre a pobreza. A imputação é realizada utilizando a abordagem da imputação múltipla (*Multiple Imputation*, MI, em inglês) proposta por Rubin (1987) e Schafer (1999). O processo é repetido para todos os agregados familiares nas amostras urbanas e rurais vinte vezes. Para estimar os indicadores a nível nacional, os resultados do processo de imputação múltipla dos modelos urbano e rural são agregados e ponderados utilizando as quotas da população urbana e rural dos *World Urbanization Prospects* para cada ano entre 2015 e 2020.

**Os principais pressupostos para o desempenho adequado dos modelos incluem que a relação entre as despesas dos agregados familiares e os correlatos da pobreza é linear e estável ao longo do tempo.** Em uma perspectiva mais ampla, isso está relacionado ao conceito do decaimento do modelo, em que o desempenho se degrada ao longo do tempo. O modelo prevê muito bem nas fases iniciais. Ainda assim, os resultados podem tornar-se menos precisos à medida que o tempo passa, devido a variações na relação com as características e variáveis do modelo. Isso ocorre, por exemplo, quando as relações de interdependência entre atributos e variáveis-alvo mudam. Algumas razões incluem variação na relação entre as variáveis e a variável-alvo, mudanças na

distribuição dos dados e ruído aleatório. Para minimizar a mudança nos correlatos das variáveis, os modelos evitam utilizar variáveis cuja relação com a pobreza tenha variado significativamente durante o período da análise, como a posse de telemóveis. Além disso, como os inquéritos IDRF e IMC seguem o mesmo quadro amostral entre 2016 e 2020, a mudança nos grupos que respondem aos inquéritos é minimizada.<sup>10</sup>

**Figura 2: Taxas de ocupação hoteleira**



Fonte: Cálculos do pessoal do Banco Mundial e do INE-CV, utilizando dados do INE-CV sobre o setor turístico.

## Métodos alternativos de estimação

Nesta secção, discutimos duas abordagens **alternativas** para modelar a evolução das taxas da pobreza em Cabo Verde durante o período **2016-2022**. Os resultados dos métodos são apresentados como uma verificação de robustez para avaliar a consistência das principais estimativas apresentadas.

<sup>10</sup> O IMC 2022 teve como base o novo Censo 2021 e assim, seguiu um quadro de amostra distinto das vagas anteriores do inquérito. Como tal, estimativas da pobreza nacionais são produzidas pela reponderação da população usando informações do World Urbanization Prospects: 2018 Revision, da Divisão de População das Nações Unidas. Por favor, consulte a secção Dados e pressupostos do modelo para mais informações.

Primeiramente, utilizamos a abordagem da distribuição neutra (*neutral distribution*), em que o consumo *per capita* dos agregados familiares observado no IDRF em 2015 foi projetado nos anos subsequentes, baseado no crescimento do PIB real do país, e, então as taxas da pobreza foram calculadas para cada ano. Neste modelo, utilizamos uma taxa de repercussão anual (*pass-through*) de 0.87, ou seja, estimamos que o consumo *per capita* dos agregados familiares em um determinado ano corresponde ao consumo estimado no ano anterior, acrescido de 87% do crescimento real do PIB verificado neste ano. É importante notar que, como este modelo atualiza o consumo de todos os agregados pelo mesmo valor todos os anos, ele mantém estável a distribuição de bem-estar ao longo dos anos, de modo que ele não permite observar possíveis mudanças na estrutura da distribuição ao longo do tempo.

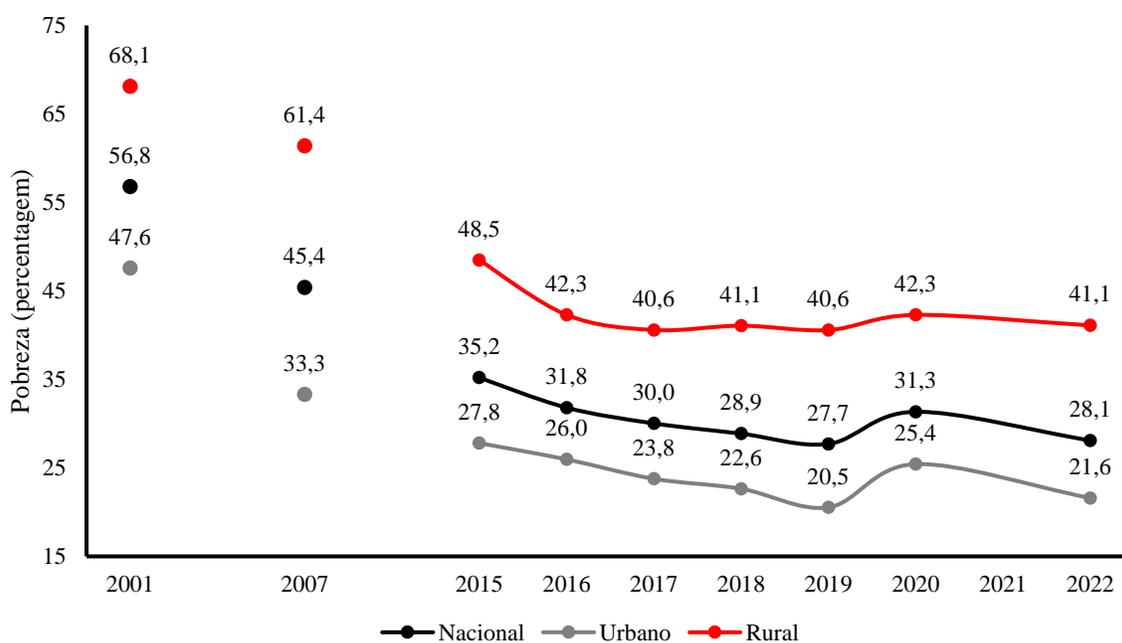
Além disto, também computamos um modelo de distribuição sectorial (*sectorial distribution*), em que as taxas da pobreza foram projetadas usando o crescimento do PIB por setor da economia (por exemplo, Agricultura, Indústria e Serviços) e a inflação esperada de alimentos e não alimentos, alocando a renda dos agregados familiares a diferentes setores, com base no setor de atividade dos indivíduos empregados dentro do agregado familiar. Assim, o modelo leva em consideração a heterogeneidade do crescimento do consumo ao nível do agregado familiar, estimando as contribuições sectoriais dos indivíduos empregados para o rendimento total do agregado familiar. Este modelo também utiliza a taxa de repercussão (*passthrough*) de 0.87 para todos os sectores, com exceção do sector primário, em que se utilizou 0.7. Um pressuposto fundamental deste método é que os indivíduos empregados continuam a trabalhar no mesmo sector de emprego ao longo do tempo. Assim, presume-se que os indivíduos empregados em setores com fraco desempenho (como a agricultura, no caso de Cabo Verde após a seca de 2018), continuem a trabalhar neste setor mesmo quando o retorno à mão de obra diminui e surgem oportunidades de melhor emprego em diferentes setores. Assim, esse método tende a ignorar mudanças na composição do mercado de trabalho e a penalizar em excesso as famílias cujos membros estavam originalmente em setores de baixo desempenho.

Os resultados usando esses dois métodos alternativos são mostrados na seção de verificação de robustez.

## ESTIMATIVAS DE POBREZA

De 2001 a 2015, Cabo Verde registou um crescimento significativo a favor dos pobres. A taxa nacional da pobreza caiu de 56,8% em 2001 para 35,2% em 2015 (última vez que as estimativas oficiais da pobreza foram divulgadas), enquanto a pobreza extrema medida usando a linha da pobreza internacional de US\$ 2,15 por pessoa por dia (PPP de 2017) caiu de 19,6% para 4,5%. No entanto, desde 2015 (quando foi implementado o último inquérito aos orçamentos familiares) existem escassas evidências empíricas sobre a evolução da pobreza no país.

Figura 3: Projeções da pobreza com a metodologia SWIFT 2001-2022 por zonas urbanas e rurais



Fonte: Cálculos do pessoal do Banco Mundial e do INE-CV, com base no IDRFB 2015 e no IMC 2016-2022 aplicando o SWIFT.

**Estimativas preliminares indicam que, antes da pandemia de COVID-19, a pobreza diminuiu em 7,5 pontos percentuais, atingindo 27,7% em 2019 (Figura 3).** Após o início da pandemia, o turismo foi interrompido, resultando numa contração do PIB de 19,3%, a segunda maior da região<sup>11</sup>. Como consequência, estimativas preliminares sugerem que a pobreza aumentou 3,6 pontos percentuais entre 2019 e 2020, levando aproximadamente 20,700 indivíduos à pobreza, quase revertendo os ganhos na redução da pobreza dos 4 anos anteriores. Após o declínio relacionado com a COVID-19, o crescimento económico foi retomado em 2021 e 2022. Embora de maior magnitude, as estimativas dos modelos neutros e sectoriais de crescimento revelam também um aumento da pobreza entre 6 e 8 pontos percentuais, sugerindo uma perda de quinquénio em termos de esforços da redução da pobreza. Além disso, as estimativas do modelo SWIFT sugerem que as zonas urbanas foram as mais atingidas, apresentando um aumento da pobreza de 4,9 pontos percentuais entre 2019 e 2020, em comparação com 1,7 pontos percentuais nas zonas rurais (Figura 4. b), pelo que o aumento da pobreza está associado a um novo tipo de agregados familiares pobres, com maior probabilidade de serem urbanos. De acordo com o modelo SWIFT, é esperado que a taxa da pobreza tenha caído para 28,1% em 2022, mas permanece acima dos níveis pré-pandemia de 2019. Um padrão semelhante é encontrado com o modelo de inflação setorial.

**Tabela 1: Características sociodemográficas dos pobres (percentual)**

	2015		2019		2022	
	Pobre	Não-pobres	Pobre	Não-pobres	Pobre	Não-pobres
Localização						
Urbano	51%	72%	50%	72%	52%	59%
Rural	49%	28%	50%	28%	48%	41%
Sexo						
Masculino	39%	48%	43%	52%	34%	45%
Feminino	61%	52%	57%	48%	66%	55%
Formação Académica						
Alfabetizado	66%	81%	72%	81%	73%	83%
Serviços						
Água potável	82%	89%	84%	86%	87%	75%
Melhoria do saneamento	58%	86%	70%	75%	73%	75%
Acesso à eletricidade	82%	95%	90%	93%	91%	92%

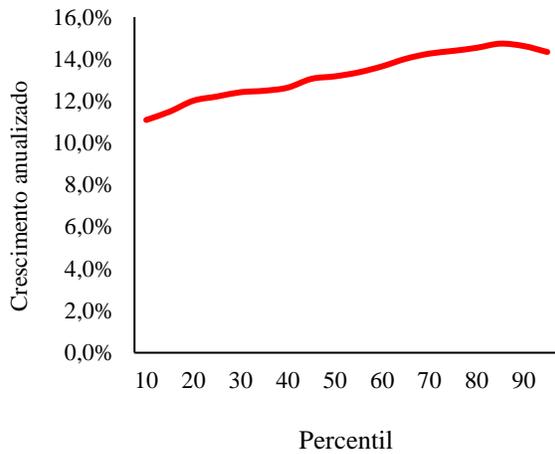
**Fonte:** Cálculos do pessoal do Banco Mundial e do INE-CV, com base no IDRF 2015 e no IMC 2016-2022 aplicando o SWIFT.

<sup>11</sup> Banco Mundial. 2022. Cabo Verde Economic Update - Cabo Verde's Potential Digital Dividends (Inglês). Banco Mundial, Washington, DC.

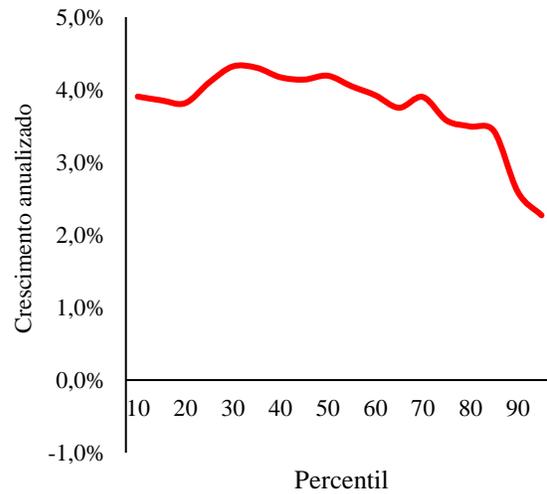
**Este novo tipo de pobres é mais urbano, mais propenso a ser representado por mulheres e empregados no sector dos serviços (especialmente no turismo), bem como mais instruído.** O género desempenhou um papel fundamental na definição do estatuto da pobreza em Cabo Verde em 2015, onde 61% dos agregados familiares pobres eram liderados por mulheres, contra 39% por homens, conforme mostra a Tabela 1. Embora esta diferença tenha diminuído até 2019, as estimativas para 2020 e 2022 sugerem que a percentagem de agregados familiares pobres representados por mulheres ultrapassou os níveis de 2015, atingindo 62% e 66%, respetivamente. Isso mostra os grupos mais vulneráveis atingidos pela desaceleração económica induzida pela COVID-19 e uma lenta recuperação. Este padrão pode ser explicado pela grande proporção de mulheres empregadas no setor de serviços (84,3%), que foi o setor mais atingido durante a pandemia de COVID-19. Em termos da localização, em 2015 e 2019, os agregados familiares pobres estavam quase uniformemente distribuídos entre as áreas urbanas e rurais. No entanto, com o início da pandemia de COVID-19, as famílias pobres tornaram-se, em média, mais urbanas, constituindo 55% das famílias pobres. Por outro lado, a percentagem de agregados familiares rurais pobres manteve-se consistente.

**Figura 4.: Curvas de incidência de crescimento**

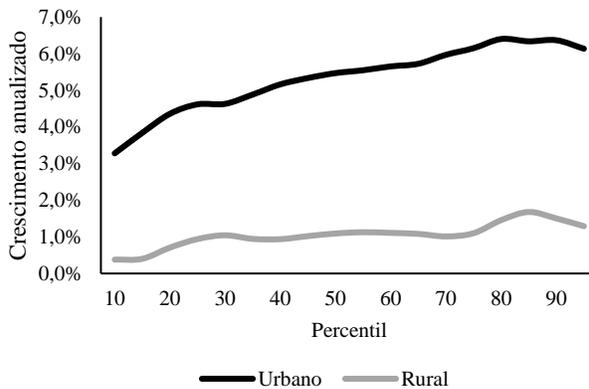
**a. Consumo nacional *per capita* anual, 2020 e 2022**



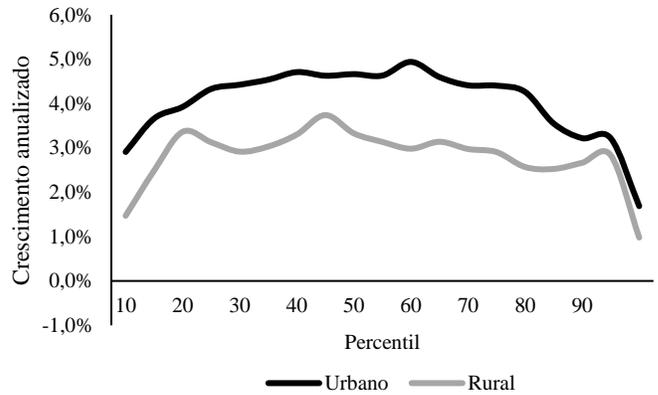
**b. Consumo nacional *per capita* anual, 2015 e 2019**



**c. Consumo *per capita* anual: Zonas Urbanas vs. Rurais, 2020 e 2022**



**d. Consumo *per capita* anual, Zonas Urbanas vs. Rurais, 2015 e 2019**



**Fonte:** Cálculos com base no IDRF 2015 e IMC 2016-2022 aplicando SWIFT.

**Notas:** Os percentis foram calculados separadamente para áreas urbanas e rurais. Os valores de 2019 e 2020 são projeções baseadas na metodologia SWIFT. Os percentis 5º mais baixo e 95º mais alto foram excluídos da análise.

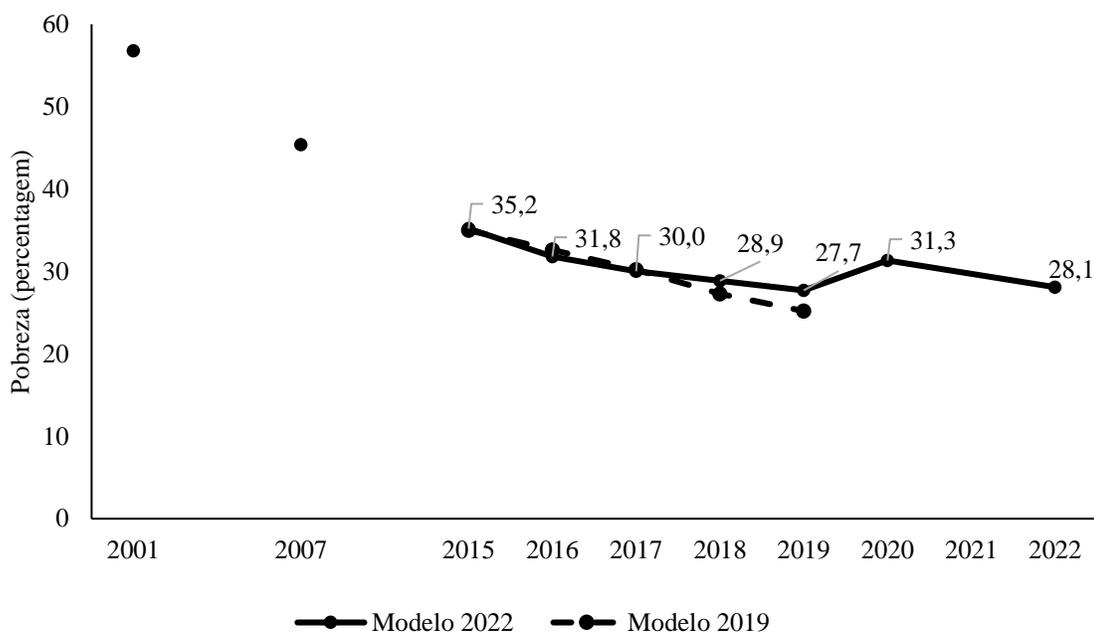
**Há evidências de crescimento pró-pobres entre 2015 e 2019, sugerindo melhorias na desigualdade de consumo.** O crescimento anualizado do consumo *per capita* foi marginalmente maior para os 40% mais pobres da distribuição de consumo (3,9%) versus os 60% mais ricos (3,4%) antes da pandemia (Figura 4.a). Entre 2020 e 2022, as áreas urbanas experimentaram maiores aumentos no consumo em comparação com as áreas rurais. Isso pode ser explicado porque a COVID-19 afetou desproporcionalmente as áreas urbanas devido ao impacto das medidas de *lockdown* e ao interrompimento completo do sector de turismo. Ao mesmo tempo, as atividades económicas associadas aos serviços e, em especial, ao turismo, também recuperaram mais

rapidamente, como mostra a Figura 4.c. Além disso, as taxas de crescimento do consumo entre as famílias urbanas nos 10% mais pobres da distribuição foram menores do que para os percentis mais ricos (onde as taxas de crescimento foram mais do que o dobro em magnitude), sugerindo uma recuperação econômica desigual em toda a distribuição. Um padrão diferente emergiu com o consumo per capita anualizado até 2019, onde o crescimento foi pró-pobres (Figura 4.b). Entre 2015 e 2019, o crescimento do consumo nas zonas urbanas foi superior ao das zonas rurais, mas menos desigual (Figura 4.d). Durante este período, os percentis inferior e superior beneficiaram menos, enquanto a classe média registou os maiores ganhos no consumo.

### **Verificações de robustez**

A primeira verificação de robustez consiste em estimar um modelo SWIFT utilizando o conjunto de variáveis disponíveis no inquérito IMC entre o período de 2016-2019. Durante esses anos, o questionário IMC inclui módulos sobre as características do agregado familiar e da habitação, incluindo o acesso aos serviços. Devido às perturbações causadas pela COVID-19, a vaga de 2020 do IMC omitiu os módulos sobre características habitacionais e acesso aos serviços e focou-se apenas no mercado de trabalho. Além disso, o IMC não foi realizado em 2021. Figura 5 compara os resultados da implementação do SWIFT com as informações disponíveis no IMC 2016 a 2019 (rotulado Modelo 2019) e compara-os com as estimativas pontuais do principal modelo implementado no documento (rotulado Modelo 2022). Os resultados mostram que ambos os modelos seguem uma trajetória semelhante, dando confiança nas previsões de pobreza usando os módulos IMC disponíveis no período 2016-2022.

**Figura 5: Comparação dos modelos utilizando dados disponíveis em 2015-2019 e 2015-2022**

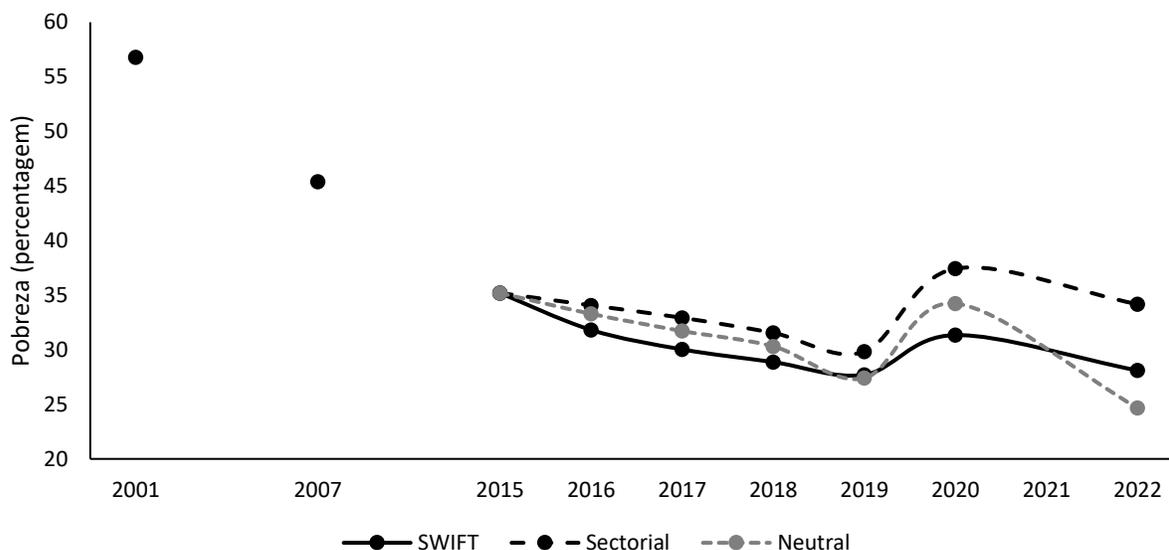


**Fonte:** Cálculos do pessoal do Banco Mundial e do INE-CV baseados no IDRF 2015 e no IMC 2016-2022 aplicando o SWIFT.  
**Nota:** O Modelo 2019 inclui, para além das variáveis do Modelo 2022, as características da habitação dos agregados familiares.

A segunda verificação de robustez utiliza outros modelos de projeção da pobreza, apresentados na subsecção “Métodos Alternativos de Estimação”, para balizar as estimativas encontradas com o modelo SWIFT. Conforme explicado anteriormente, os modelos utilizam as informações provenientes das taxas de crescimento real do PIB agregado e sectorial para atualizar o consumo dos agregados familiares ao longo dos anos e, assim, prever a taxa de pobreza no país. A Figura 6 compara as projeções da pobreza utilizando o PIB agregado com os resultados do modelo SWIFT. Para o modelo de crescimento setorial (rotulado setorial), as categorias de emprego foram agrupadas em agricultura, serviços e indústria. Para os desempregados e inativos, pressupôs-se um crescimento do PIB a nível nacional. Em ambos os modelos, parte-se do princípio de que os trabalhadores empregados não mudam de sector. Para o modelo de crescimento sectorial, o consumo das famílias cresce ao mesmo ritmo que o crescimento do PIB sectorial, dependendo do sector de atividade dos membros dos agregados familiares que estejam empregados. Se todos os membros do agregado estiverem desempregados ou fora da força de trabalho, o consumo cresce ao mesmo ritmo que o crescimento do PIB nacional. Além disto, este modelo leva em consideração a inflação alimentar e não alimentar, refletindo a atual evolução macroeconómica desde 2020. Em

contrapartida, o segundo modelo apresentado aplica a taxa de crescimento do PIB real aos rendimentos das famílias (denominado Neutro). Pela estimativa, pressupõe-se uma taxa de repercussão de 0,87 para o modelo de distribuição neutra e para todos os setores no modelo sectorial, exceto o setor primário, onde se supunha ser de 0,7.

**Figura 6: Comparação das projeções de pobreza com a metodologia SWIFT, distribuição setorial e neutra, 2001-2020**



**Fonte:** Cálculos do pessoal do Banco Mundial e do INE-CV, com base no IDRF 2015 e no IMC 2016-2020 aplicando o SWIFT.

Os resultados mostram que, após o início da pandemia, o turismo foi interrompido, resultando numa contração do PIB de 19,3%, a segunda maior da região, com um correspondente aumento da taxa de pobreza entre 2019-2020<sup>12</sup>. No período anterior a 2019, ambos os modelos que utilizam informações sobre o PIB apresentam reduções de pobreza mais baixas do que os resultados do SWIFT. Este é particularmente o caso do modelo que utiliza taxas de crescimento setoriais e inflação, uma vez que penaliza as famílias com indivíduos empregados em 2015 num setor que mais tarde teve um desempenho inferior, como a agricultura.<sup>13</sup> Um comportamento semelhante pode ser visto após 2020, onde as estimativas de redução da pobreza são mais baixas com o modelo setorial, dado que considera os efeitos da inflação.

<sup>12</sup> Banco Mundial. 2022. Cabo Verde Economic Update - Cabo Verde's Potential Digital Dividends (Inglês). Banco Mundial, Washington, DC.

<sup>13</sup> Presume-se que os membros dos agregados familiares continuem a trabalhar neste setor, mesmo quando o retorno ao trabalho diminui e as oportunidades de melhor emprego em diferentes setores surgem.

## CONCLUSÃO

**Acompanhar a evolução da pobreza e da desigualdade é fundamental para informar as políticas públicas.** No entanto, as estatísticas sobre a pobreza exigem dados fiáveis sobre as despesas ou o rendimento das famílias, que são complexas e morosas tanto do ponto de vista das agências das estatísticas como dos agregados familiares que fornecem as suas informações e respondem aos questionários pormenorizados sobre consumo. Esta nota tenta preencher esta falta de dados através da produção de indicadores anuais da pobreza entre 2016 e 2022. Considerando a importância da medição da pobreza monetária para avaliar o desempenho socioeconómico, utiliza a metodologia SWIFT-plus, um desenvolvimento metodológico recente para colmatar a falta de dados e avaliar a evolução da pobreza monetária ao longo do tempo.

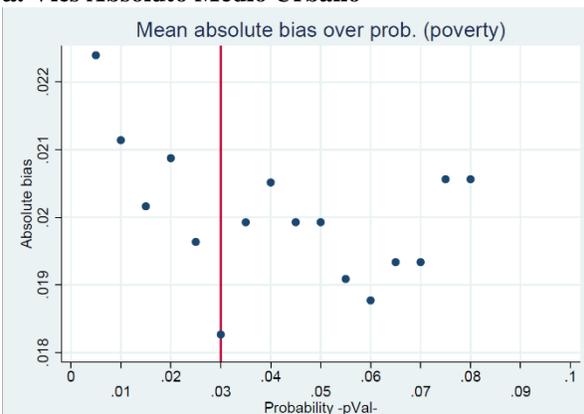
**Esta metodologia não está isenta de limitações.** De acordo com os pressupostos e limitações da metodologia, podemos interpretar melhor as estimativas. Em primeiro lugar, esta aplicação da abordagem SWIFT destina-se a estimar a taxa da pobreza absoluta, e não valores nos extremos da distribuição do bem-estar, como a pobreza extrema. Em segundo lugar, esta implementação do SWIFT não incorpora os efeitos da inflação, ao contrário de outras técnicas de estimativa utilizadas pelo Banco Mundial. Em terceiro lugar, para o caso específico de Cabo Verde, estas estimativas baseiam-se num valor observado que data de 2015. Como tal, quanto mais dados de inquéritos secundários por ano forem adicionados ao modelo, menor será o poder preditivo do modelo.

# APÊNDICE

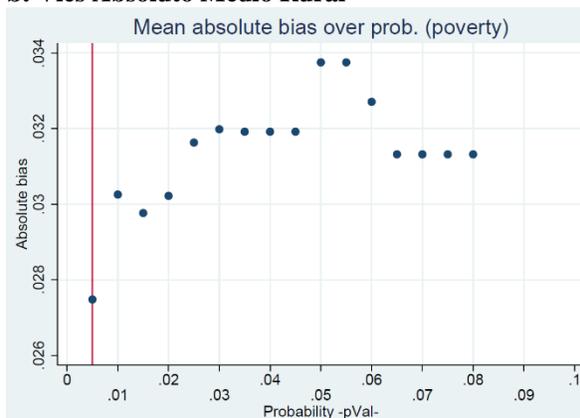
Figura 7.: Resultados da seleção do modelo de validação cruzada

Modelo 2015-2022

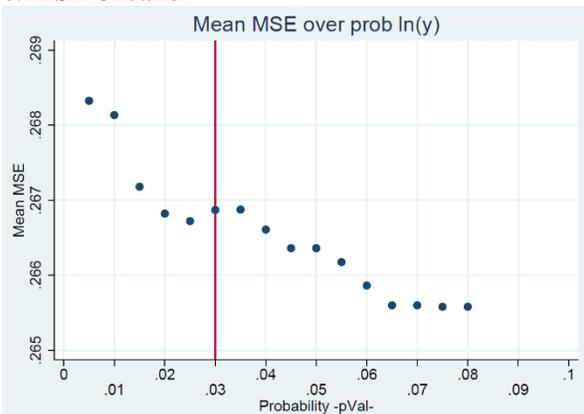
**a. Viés Absoluto Médio Urbano**



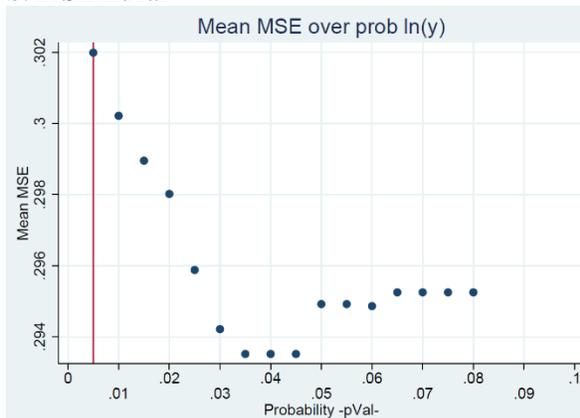
**b. Viés Absoluto Médio Rural**



**c. MSE Urbano**



**b. MSE Rural**



Fonte: Cálculos do Pessoal do Banco Mundial e do INE-CV.

Nota: Resultados da validação cruzada da análise com 5 iterações utilizando dados IDRF 2015. A linha vermelha vertical identifica o valor p ideal identificado. O MSE (sigla inglês, Mean Squared Error) significa Erro Quadrático Médio.

**Tabela 2: Resultados do modelo: Áreas urbanas e rurais**

Urbano		Rural	
Variável	Coefficiente	Variável	Coefficiente
Log de tamanho do AF (ao quadrado)	-0.175 (0.010)	Log de tamanho do AF (ao quadrado)	-0.073 (0.013)
Log de idade	0.441 (0.040)	Percentagem membros: 15 a 24 anos	0.603 (0.089)
Percentagem membros com menos de 5 anos	-0.614 (0.085)	Percentagem de membros:25 a 64 anos	1.086 (0.087)
Percentagem de membros: 6 a 14 anos	-0.503 (0.064)	Percentagem de membros com mais de 65 anos	1.238 (0.108)
Percentagem de membros: 25 a 64 anos	0.361 (0.046)	Formação: Secundário	0.304 (0.049)
Formação: Primária	0.200 (0.036)	Formação: Superior	0.898 (0.081)
Formação: Secundário	0.545 (0.042)	Principal fonte de rendimento: Pensão	-0.185 (0.051)
Formação: Superior	1.113 (0.047)	Trabalho: Família e não remunerado	-0.178 (0.051)
Desempregado	-0.198 (0.048)	Concelho: Paúl	-0.438 (0.059)
Trabalhador(a) por conta própria	0.146 (0.030)	Concelho: Porto Novo	-0.240 (0.070)
Principal fonte de rendimento: Rendas	0.192 (0.083)	Concelho: Tarrafal de São Nicolau	-0.495 (0.093)
Principal fonte de rendimento: Remessas (int.)	0.155 (0.062)	Concelho: Boavista	0.247 (0.063)
Trabalho: Família e não remunerado	-0.173 (0.048)	Concelho: Santa Cruz	-0.212 (0.073)
Trabalho: Empresa privada	0.082 (0.027)	Concelho: São Salvador do Mundo	-0.243 (0.059)
Taxa de ocupação hoteleira	0.732 (0.068)	Concelho: São Filipe	-0.426 (0.054)
Concelho: Porto Novo	-0.244 (0.056)	Concelho: Brava	-0.191 (0.051)
Concelho: São Vicente	-0.089 (0.024)	Constante	11.031 (0.075)
Concelho: Paúl	-0.169 (0.051)	Observações	2,295
Concelho: São Salvador do Mundo	-0.282 (0.110)	R-quadrado	0.328
Concelho: Ribeira Grande de Santiago	0.240 (0.087)		
Concelho: São Filipe	-0.118 (0.053)		
Constante	10.103 (0.174)		
Observações	3,900		
R-quadrado	0.515		

Fonte: Cálculos do Pessoal do Banco Mundial e do INE-CV.